

A DIMENSÃO SOCIAL DAS EMISSÕES DE CO₂ DO TRÁFEGO DE VEÍCULOS: modelos inteligentes de alta definição na cidade do Rio de Janeiro

THE SOCIAL DIMENSION OF CO₂ EMISSIONS BY VEHICLE TRAFFIC: intelligent high-definition models in the city of Rio de Janeiro

LA DIMENSIÓN SOCIAL DE LAS EMISIONES DE CO₂ POR EL TRÁFICO DE VEHÍCULOS: modelos inteligentes de alta definición en la ciudad de Río de Janeiro

RESUMO

As emissões urbanas de CO₂ têm sido percebidas como um ponto central no Ciclo Global de Carbono, embora ainda compreendamos pouco sobre a emissão socioeconômica no espaço e tempo. Este trabalho tem por objetivo modelar as emissões de CO₂ originárias do tráfego de veículos e avaliar sua relação com as características socioeconômicas da população da cidade do Rio de Janeiro no período entre 7 a 31 de janeiro de 2021. Utilizou-se um modelo de mapeamento para estimar as emissões ao nível da via usando algoritmos de Aprendizagem de Máquinas, dados de mobilidade, Sistema de Informação Geográfica e R. As emissões foram agregadas às áreas e regiões de planejamento, bem como à malha digital do IPEA contendo indicadores socioeconômicos, como densidade populacional, renda domiciliar per capita média e quantidade de empregos. Os resultados mostraram que o modelo ML representa com eficácia a variabilidade espaço-temporal dos fluxos horários de veículos e velocidade média ao nível da via na cidade do Rio de Janeiro, apresentando um RMSE de 138 veh h⁻¹ e de 7.0 km h⁻¹, respectivamente. O modelo estimou emissões elevadas na Avenida Brasil, principal via expressa da cidade, com o máximo de 4.750 tCO₂ km⁻². As maiores emissões ocorrem nas vias expressas que conectam a cidade em direção ao Centro e orla da Zona Sul e Barra da Tijuca, antiga e nova centralidades, onde há maior oferta de trabalho.

Palavras-chave: Emissão de carbono. Mudanças climáticas. Tráfego de veículos. Indicadores sociais. Aprendizagem de máquinas.

ABSTRACT

CO₂ emissions from urban areas have been perceived as a central point in the Global Carbon Cycle, although we still understand little about their social dimension in space and time. The work aims to model CO₂ emissions from road traffic and evaluate the relationship between socio-economic characteristics of the population living in the city of Rio de Janeiro between 7 and 31 January 2021. A mapping model was used to estimate CO₂ emissions at the street level, using Machine Learning algorithms, mobility data, Geographic Information System, and R. Emissions were aggregated to planning areas and regions, as well as to the IPEA digital mesh containing socioeconomic indicators, such as population density, average per capita household income and number of jobs. The results showed that the ML model effectively represents the spatio-temporal variability of hourly vehicle flows and average speed at road level in the city of Rio de Janeiro, presenting an RMSE of 138 veh h⁻¹ and 7.0 km h⁻¹, respectively. The model estimated high emissions on Avenida Brasil, the city's main expressway, with a maximum of 4,750 tCO₂ km⁻². The biggest emissions occur on the expressways that connect the city towards the Center and the edge of the South Zone and Barra da Tijuca, old and new centralities, where there is a greater job offer.

Keywords: Carbon emission. Climate change. Vehicle traffic. Social indicators. Machine learning.

RESUMEN

Las emisiones de CO₂ de las áreas urbanas se perciben como un punto central en el

 Heitor Soares de Farias^a

 Max Anjos^b

^a Universidade Federal Rural do Rio de Janeiro (UFRRJ), Seropédica, RJ, Brasil

^b Universidade Técnica de Berlim, Berlim, Alemanha; Universidade Federal do Rio Grande do Norte (UFRN), Natal, RN, Brasil

DOI: 10.12957/geouerj.2024.77757

Correspondência: heisofa@ufrj.br

Recebido em: 15 jul. 2023

Revisado em: 08 mar. 2024

Aceito em: 12 set. 2024





Ciclo Global del Carbono, aunque aún entendemos poco acerca de su dimensión social en el espacio y el tiempo. El objetivo de este trabajo es modelar las emisiones de CO₂ del tráfico rodado y evaluar la relación entre las características socioeconómicas de la población que vive en la ciudad de Río de Janeiro entre el 7 y el 31 de enero de 2021. Se utilizó un modelo de mapeo para estimar las emisiones de CO₂ a nivel de calle, utilizando algoritmos de Aprendizaje Automático (Machine Learning), datos de movilidad, Sistemas de Información Geográfica y R. Las emisiones estimadas se agregaron a las áreas y regiones de planificación, así como a la malla digital del IPEA que contiene indicadores socioeconómicos, como la densidad de población, el ingreso familiar promedio per cápita y el número de empleos. Los resultados mostraron que el modelo ML representa efectivamente la variabilidad espacio-temporal de los flujos vehiculares horarios y la velocidad promedio a nivel de vía en la ciudad de Río de Janeiro, presentando un RMSE de 138 veh h⁻¹ y 7,0 km h⁻¹, respectivamente. El modelo estimó altas emisiones en la Avenida Brasil, la principal vía rápida de la ciudad, con un máximo de 4.750 tCO₂ km⁻². Las mayores emisiones ocurren en las vías rápidas que conectan la ciudad hacia el Centro y el borde de la Zona Sur y Barra da Tijuca, antiguas y nuevas centralidades, donde hay mayor oferta de empleo.

Palabras Clave: Emisiones de carbono. Cambios climáticos. Tráfico de vehículos. Indicadores sociales. Aprendizaje automático.



INTRODUÇÃO

O setor de transporte é um dos principais contribuintes para as emissões globais de dióxido de carbono (CO₂) provenientes de combustíveis fósseis, sendo que os veículos rodoviários sozinhos são responsáveis por três quartos das emissões nesse setor (EEA, 2017; IEA, 2019). Essa contribuição é especialmente evidente em áreas urbanas, onde a alta concentração de veículos e as maiores distâncias percorridas resultam em níveis expressivos de emissões de CO₂, tornando o transporte rodoviário um componente importante da contabilização de carbono nas cidades (GATELY et al., 2015; GURNEY et al., 2012; HUO et al., 2022; NANGINI et al., 2019).

As áreas urbanas possuem paisagens com muitas e diversificadas fontes de emissão de gases para a atmosfera, e as elevadas concentrações de CO₂ são resultado da composição dessas várias plumas (FENG et al., 2015). As emissões de CO₂ têm grande variabilidade no espaço e tempo, pois as áreas urbanas são uma combinação de assentamentos humanos, uso do solo, espaços naturais, infraestruturas, rede de transportes, indústrias, aos quais têm associados padrões específicos de emissões atmosféricas.

Assim, hodiernamente, tem ampliado o número de trabalhos dedicados a investigar as características socioeconômicas da população e sua relação com os padrões de emissões de carbono (WANG et al., 2017; LU et al., 2018). Características como densidade populacional, uso do solo, renda média são importantes vetores de emissões, pois determinam como a energia é usada e consumida na cidade.

Apesar dos promissores avanços sobre a dimensão social das emissões urbanas nos últimos anos, a relação entre as características socioeconômicas e a variação de emissões de CO₂ é ainda insuficiente estudada, principalmente em cidades tropicais. Isso se deve, em grande medida, à falta de dados sobre CO₂ e a resolução espaço-temporal limitada, o que pode revelar resultados imprecisos ou incompletos quando se pretende correlacionar as emissões com os fatores socioeconômicos. Por exemplo, muitas cidades utilizam ainda dados de CO₂ agregados em bases metodológicas (os inventários de emissões) que não captam a variabilidade intra-anual e locais das emissões em todo domínio urbano (TURNBULL et al., 2022).

A alta resolução espacial e temporal das emissões de CO₂ pode ser alcançada com o aumento na densidade de estações de monitoramento (LAUVAUX et al., 2016), com a realização de detalhados inventários de fontes emissoras (GATELY et al., 2015; SARGENT et al., 2018), combinando conjuntos de dados e ferramentas de simulação para gerar modelos que possam ser reaplicados em qualquer grande cidade (GURNEY et al., 2012; HARDIMAN et al., 2017), ou, mais recentemente, com o Aprendizado de Máquinas (*Machine Learning*, em inglês, doravante referenciado como ML) (MENZER et al., 2015; WU et al., 2021). O ML



é um subcampo da Inteligência Artificial que lida eficazmente com o processamento e a identificação de padrões espaço-temporais em grandes volumes de dados (CHOLLET e ALLAIRE, 2017), tal como os de transporte rodoviário. Alguns trabalhos têm aplicado as técnicas de ML, como o uso de algoritmos que são capazes de prever com relativa precisão as estimativas de tráfego de veículos (LIU e WU, 2017, WEN et al., 2022).

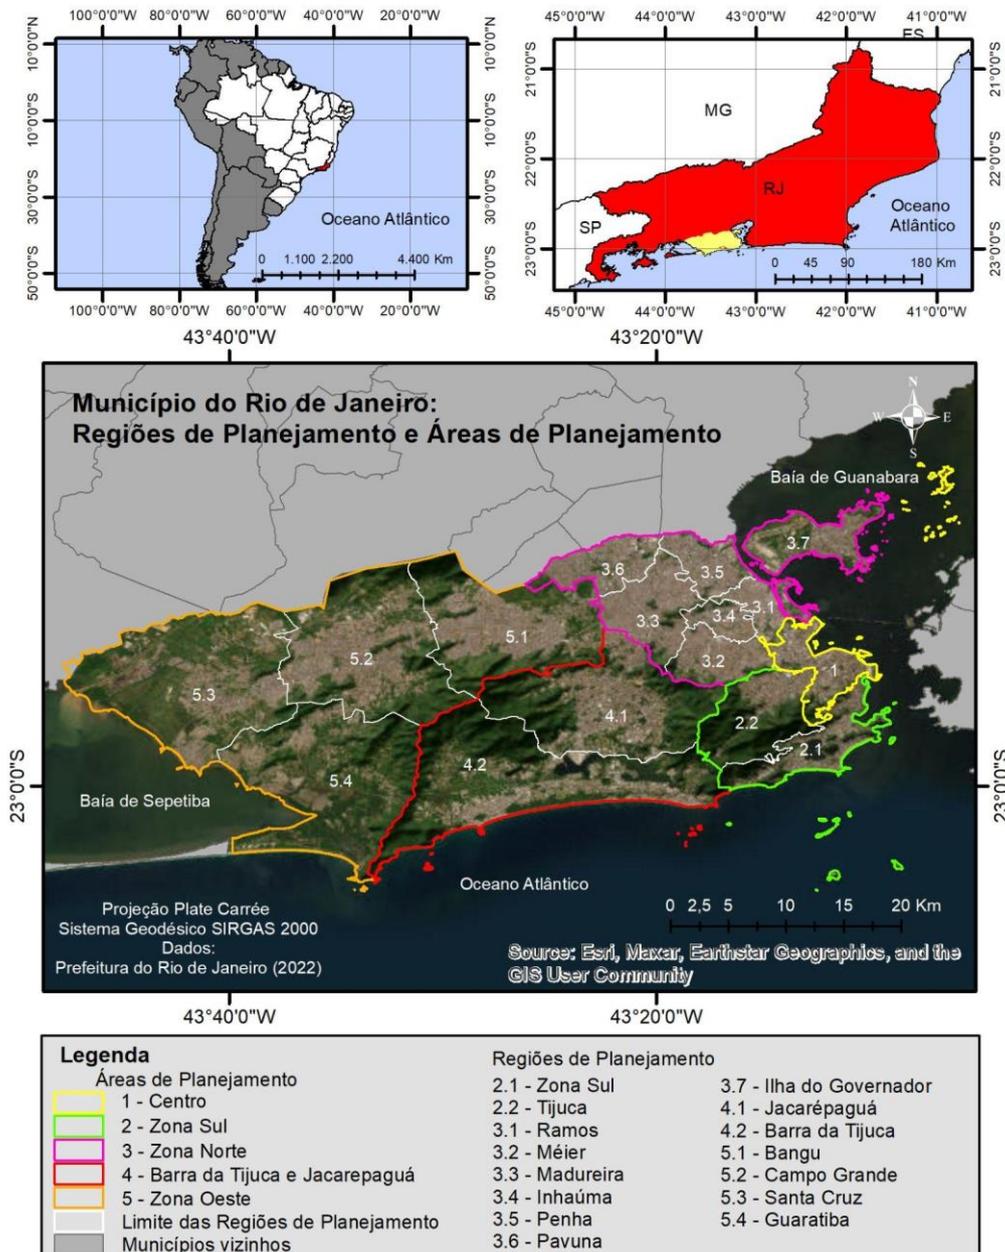
Assim, este estudo avançou no entendimento da relação entre as características socioeconômicas e a variação das emissões de CO₂, a partir da utilização de ML. O objetivo foi estimar as emissões horárias de CO₂ originadas pelo transporte rodoviário em alta resolução espacial e temporal, ao nível das vias com frequência horária, correlacionando as emissões com as variáveis socioeconômicas espacializadas pelas Regiões de Planejamento (RP) e Áreas de Planejamento (AP) na cidade do Rio de Janeiro.

MATERIAIS E MÉTODOS

Área de Estudo

A cidade do Rio de Janeiro localiza-se em uma planície litorânea banhada pelo Oceano Atlântico, entre as baías de Guanabara e Sepetiba, e, ao fundo, cercada pela Serra do Mar, que se eleva a uma altitude média de 900 metros (Figura 1). Nesta planície encontram-se três maciços rochosos - Tijuca, Pedra Branca e Gericinó-Mendanha -, com altitudes em torno de 1000 metros, que impõem resistência ao fluxo atmosférico, reduzindo a velocidade do vento, impedindo que a brisa do mar atinja os bairros e municípios localizados dentro da MARJ, contribuindo para a estagnação dos poluentes (FARIAS, 2013).

Figura 1 – Localização da cidade do Rio de Janeiro e suas RPs e Aps



Fonte: Base cartográfica- OpenStreetMap (2017); e Prefeitura do Rio de Janeiro (2022)
Elaborado pelos autores, 2024.

O sítio foi escolhido por suas características defensivas e, ao longo da história de expansão da cidade, muitos foram os desafios que mostraram sua inadequação para a formação de uma metrópole (BERNARDES, 1990). O suporte físico facilitou o desenvolvimento de um conjunto urbano compartimentado, onde se



concretizam as estratificações sociais projetadas no território (ABREU, 1987). Assim, os maciços rochosos dividem a cidade em cinco Áreas de Planejamento (AP) com conteúdos sociais muito distintos, subdivididas em Regiões de Planejamento (RP), para as quais são destinadas políticas públicas e privadas tais como as de mobilidade e ambiental.

A AP 1, ou Centro, tem perfil comercial e baixa densidade de residências, com 3% do território e 5% da população, recebe grande público flutuante (RIO DE JANEIRO, 2011). A partir do Centro, para o sul, pelo litoral ocorreu a ocupação por famílias que tinham condições de se locomover para fora do núcleo urbano, o que era privilégio para poucos (ABREU, 1987). Assim foi formada a AP 2, a Zona Sul, que apresenta os melhores padrões de infraestrutura urbana e equipamentos sociais, mas também com população de baixa renda, devido à ocupação irregular nas encostas, desvalorizadas pelos riscos ambientais associados, sendo densamente ocupada, com 8% do território e 16% da população.

Saindo do Centro, contornando o maciço da Tijuca para a Zona Norte, está a AP 3. Desenvolveu-se a partir da instalação das ferrovias para ocupação das periferias, atraindo população de baixa renda e atividade industrial (ABREU, 1987). Hoje é a área mais densamente ocupada, com 17% do território e 38% da população da cidade, conurbando-se aos municípios da periferia imediata da Baixada Fluminense (SOUZA, 2003).

A AP 4 manteve-se com base rural até a década de 1960 devido às dificuldades de acesso. Com áreas naturais de grande beleza cênica e com amplas áreas disponíveis disputadas pelo mercado imobiliário - com 24% do território e 14% da população - foi o local escolhido para receber os principais equipamentos para os Jogos Olímpicos de 2016 (NOVAIS, 2014; MASCARENHAS, 2016).

A AP 5, ou Zona Oeste, foi a última área a ser urbanizada, principalmente devido à grande distância do Centro. Manteve o uso agrícola até a década de 1950, quando, devido à abertura da Avenida Brasil para expansão das atividades industriais, surgiram os primeiros centros urbanos. (ABREU, 1987). Hoje é mais uma periferia urbana da capital com baixa densidade populacional, com 48% do território e 27% da população, que se conecta com a periferia distante da metrópole (SOUZA, 2003).

Construção do modelo do ML

As emissões de CO₂ foram calculadas utilizando um modelo ML que permite extrapolar as estimativas de tráfego dos segmentos de via onde os dados estão disponíveis para aqueles segmentos onde os dados são insuficientes, baseado nas características espaço-temporais similares. O modelo ML utiliza as características de tráfego semelhantes ao nível da rua ou segmento da via (*polyline*) e estima os valores médios horários do



fluxo de veículos e a velocidade média. O modelo ML foi desenvolvido usando a linguagem computacional R (R CORE TEAM, 2023).

O modelo ML proposto usa dois bancos de dados principais: tráfego e espaciais. Os dados de tráfego foram fornecidos pela Companhia de Engenharia de Tráfego do Rio de Janeiro - CET-Rio, para os dias 07 a 31 de Janeiro de 2021, e contêm o número de veículos por hora, velocidade média e tipos de veículos, que foram medidos em 963 estações de contagem localizadas nos cruzamentos de vias e semáforos em diferentes pontos da cidade.

Os dados espaciais como rede viária (links), comprimento da via, limite de velocidade da via, classes de vias, áreas de lazer, uso e cobertura do solo, edifícios, comércio, amenidade e áreas naturais foram retirados do Geofabrik - Open Street Map (OSM) (OPENSTREETMAP, 2017). As características espaciais do OSM podem ser consultadas com mais detalhes no site https://wiki.openstreetmap.org/wiki/Map_features.

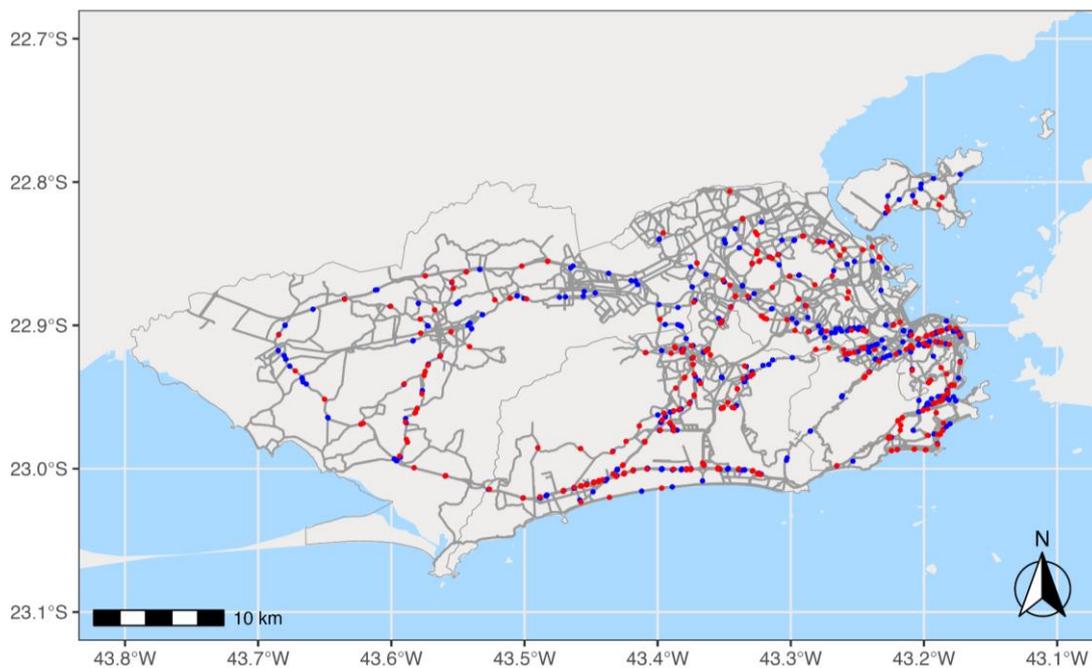
Os dados de tráfego e dados espaciais foram pré-processados nas seguintes etapas: categorização das vias, engenharia de recursos e divisão dos dados de tráfego em treinamento e teste. Os pontos de contagem de tráfego foram agregados aos segmentos das vias mais próximas por meio das funções *st_join* e *st_nearest_feature* do pacote R *sf* (PEBESMA, 2018), o que permitiu reunir as variáveis volume de veículos e a velocidade média, bem como as variáveis do OSM, densidade populacional em um único banco de dados. Em seguida, os segmentos de vias foram separados em duas categorias: "amostrados", referindo-se aos segmentos que têm pontos de contagem de tráfego, e "não amostrados", indicando aqueles que não têm contagem. A função do modelo ML é aprender com as características das vias amostradas e, então, estimar o volume médio horário dos veículos e a velocidade média para as vias não amostradas.

A engenharia de recursos destinou-se ao preenchimento de dados faltantes e a transformação estatística dos dados existentes para extrair novas variáveis e assim selecionar aquelas com maior poder preditivo. Por exemplo, as variáveis temporais, tais como hora do dia, feriados, dias da semana e fim de semana, foram extraídas da coluna data, em formato 2021-01-01 01:00:00, usando as funções do pacote R *recipes package* (KUHN & WICKHAM, 2023). Já as variáveis espaciais, como faixas de tráfego, limites máximos de velocidade e comprimentos dos segmentos de vias, foram utilizadas para calcular vários índices relacionados ao tráfego, incluindo capacidade da estrada, densidade de veículos e fluxo por faixa. Ao todo, o modelo ML foi composto por 34 variáveis espaço-temporais.

Para melhorar a generalização e aumentar a eficácia das previsões do modelo ML no mundo real, o banco de dados de tráfego foi dividido da seguinte maneira: 70% das estações de contagem de veículos foram

reservadas para o treinamento e as 30% restantes para teste (Figura 2). Os dados de treinamento referem-se ao período de 7 a 24 de janeiro de 2021, enquanto os dados de teste de 25 a 31 de janeiro de 2021. A avaliação do modelo foi baseada nos dados de teste, utilizando as métricas de raiz quadrada do erro quadrático médio (RMSE) e média do erro absoluto (MAE).

Figura 2 - Localização das estações de contagem de veículos utilizadas para o treinamento (azul) e teste (vermelho) do modelo ML e representação cartográfica da rede de transporte rodoviário na cidade do Rio de Janeiro.



Fonte: Base cartográfica- OpenStreetMap, (2017); dados de tráfego CET-Rio, 2020.
Elaborado pelos autores, 2024.

O modelo ML utilizou o Random Forest (RF), um algoritmo amplamente conhecido por sua capacidade de combinar um grande número de árvores de decisão para realizar tarefas de classificação ou regressão (BREIMAN, 2001). Os modelos baseados em árvores de decisão, como o RF, têm demonstrado considerável desempenho com dados em formato tabular (LUNDBERG et al., 2020), que consiste em linhas e colunas, como os dados de tráfego deste estudo. Além disso, o RF tem sido aplicado no campo da demanda de tráfego e pesquisa de poluentes atmosféricos (LIU e WU, 2017, WEN et al., 2022). O RF foi executado com o pacote R ranger v. 0.14.1, uma versão mais otimizada para a utilização dessa estrutura de árvores de decisão (WRIGHT e ZIEGLER, 2017). Para interpretar as predições do RF, o método permutação foi usado para calcular a importância das variáveis, uma vez que ele mede a contribuição de cada variável nas predições finais (WRIGHT e ZIEGLER, 2017).



Cálculo das emissões de CO₂

A partir das predições do modelo ML, as emissões de CO₂ originadas do tráfego de veículos ($E_{h,i,l}$, g km h⁻¹) por tipo de veículos foram calculadas conforme a seguinte equação:

$$E_{h,i,l} = \sum_{i=1}^n \frac{q_{h,i,l} * L_l * FE_{v,i}}{As} \quad (1)$$

Onde q_i é o fluxo de tráfego da categoria de veículo i em uma via l em veh h⁻¹, l é o comprimento da via em km⁻¹ e $FE_{v,i}$ é o fator de emissão para a categoria de veículo i (automóveis, veículos comerciais leves, motocicletas, caminhões e ônibus) na velocidade média v em g km⁻¹. Os FE foram gerados com base nos limites médios de velocidade km h⁻¹. No entanto, os FE desenvolvidos para o Brasil, especialmente os fornecidos pelo CETESB, não levam em consideração a velocidade do veículo. Para corrigir essa lacuna, os valores locais foram ajustados às funções de FE dependentes da velocidade do programa de computador - COPERT (*Computer Programme calculate Emissions from Road Transport*), usando as funcionalidades do modelo Vehicular Emissions INventory - VEIN (IBARRA-ESPINOSA et al., 2018). A partir desses ajustes, foram geradas funções de FE dependentes da velocidade para cada categoria de veículos.

Dados sociodemográfico e áreas de planejamento

As emissões de CO₂ provenientes do tráfego de veículos no Rio de Janeiro foram analisadas com base em características socioespaciais, como densidade populacional e renda domiciliar per capita média, quantidade de empregos, quantidade de empregos de baixa escolaridade, quantidade de empregos de média escolaridade e quantidade de empregos de alta escolaridade. Esses dados foram obtidos usando o pacote R *aopdata* v1.0.299 (PEREIRA et al., 2022), que organiza as informações em uma malha digital no formato Shapefile ESRI, com uma resolução de grade de aproximadamente 100 x 100 metros. Os dados foram refinados pelo Instituto de Pesquisa Econômica Aplicada e também contam com dados do censo de 2010 do IBGE.

Os shapefiles das Áreas de Planejamento (AP) foram baixados do portal da Prefeitura do Rio de Janeiro (<https://www.data.rio/>). A cidade é dividida em cinco APs, cada uma subdividida em RPs. Essas áreas

recebem políticas públicas e privadas específicas, como políticas de mobilidade e ambientais, que constam no Plano Diretor Municipal (RIO DE JANEIRO, 2024).

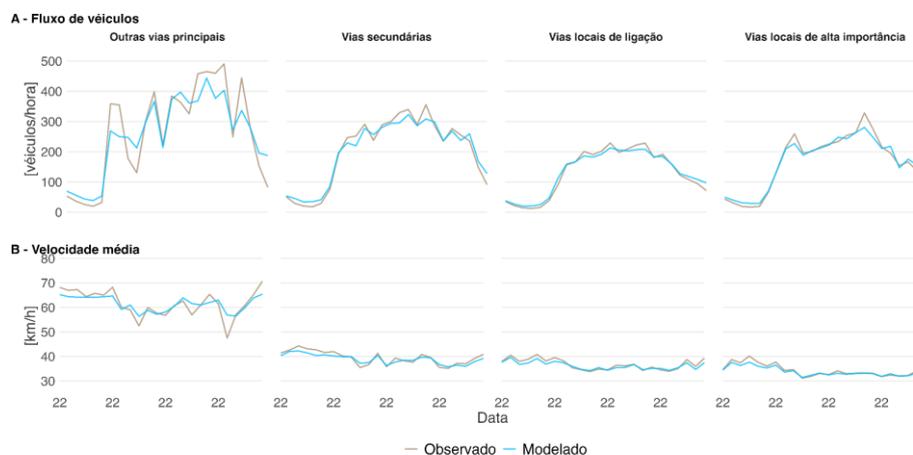
RESULTADOS E DISCUSSÃO

- Avaliação do modelo ML e a importância das variáveis

O desempenho do modelo ML foi avaliado aplicando as estimativas do RF ao conjunto de dados de teste. A Figura 3 mostra que, em geral, há uma forte concordância entre dados modelados e dados observados nos diferentes tipos de vias para fluxos horários de veículos e velocidade média. No entanto, o modelo tende a subestimar o fluxo de veículos, especialmente no horário da tarde nas vias locais de ligação. Isto pode ser parcialmente atribuído ao tamanho limitado da amostra dos segmentos de vias com estação de contagem de veículos utilizado no treinamento do RF, o que dificulta a predição da variabilidade do fluxo de veículos nessa classe de vias. Para o fluxo de veículos, o modelo de ML apresentou um RMSE de 138 veh h^{-1} e um MAE de 87 veh h^{-1} , enquanto a velocidade média teve um RMSE de 7.0 km h^{-1} e um MAE de 4.5 km h^{-1} .

Desta maneira, o ML demonstrou erros aceitáveis em comparação com outros modelos na literatura, onde os valores de RMSE e MAE para predições de fluxo de veículos e velocidade média variam amplamente (MEDINA-SALGADO et al., 2022). Esses resultados sugerem que o modelo ML representa com eficácia a variabilidade espaço-temporal dos fluxos horários de veículos e velocidade média ao nível da via na cidade do Rio de Janeiro no período analisado.

Figura 3 - Comparação entre os valores observados e modelados de fluxo horário de veículos e velocidade média em diferentes tipos de vias na cidade do Rio de Janeiro no período entre 25 e 31 de janeiro de 2021.

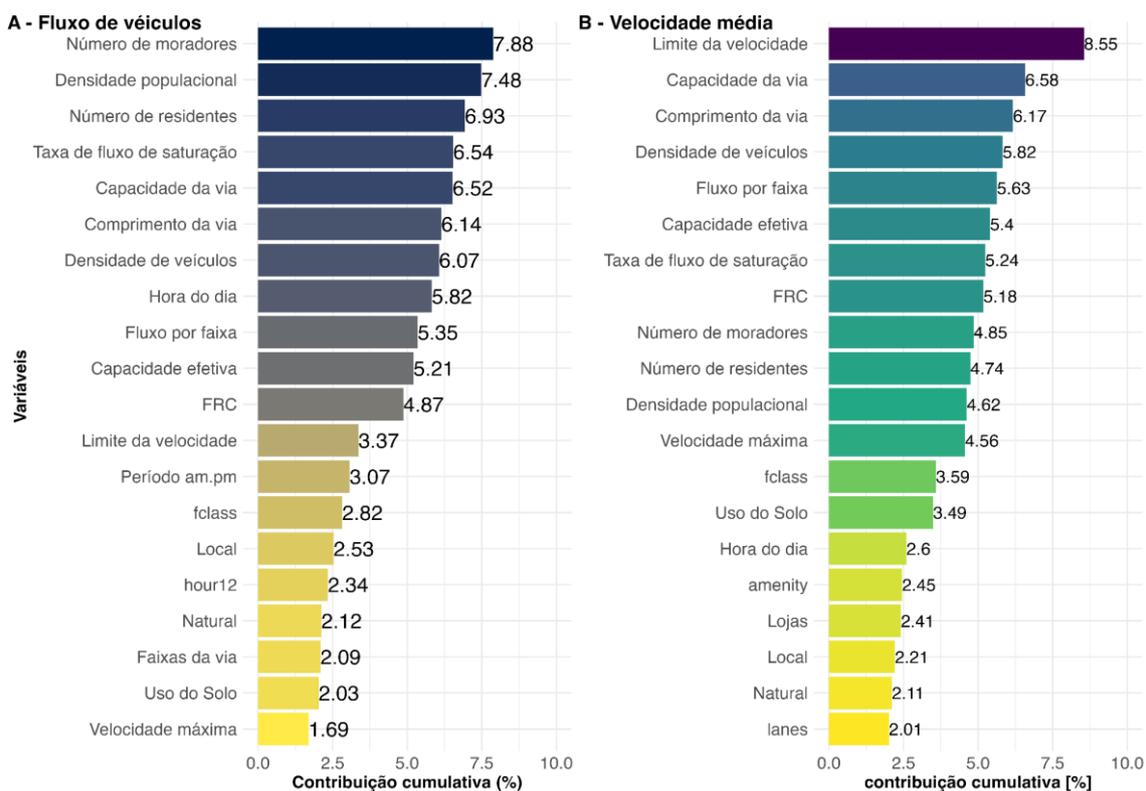


Elaborado pelos autores, 2024.



A Figura 4 mostra as principais variáveis que influenciaram nas estimativas de fluxo de veículos e velocidade média. Três delas desempenharam um papel particularmente significativo, como o número de moradores por domicílio, densidade populacional e número de residentes, com a maior contribuição cumulativa relativa de cerca de 7.8%, destacando o aspecto espacial e sociodemográfico nas estimativas de fluxo de veículos (Figura 4a). Além dessas, outras variáveis como taxa de fluxo de saturação, capacidade da via e comprimento da via, também influenciaram as previsões de fluxo de veículos, contribuindo cada uma com aproximadamente 6.0%. Em relação à velocidade média (Figura 4b), o limite de velocidade foi a variável mais influente, com uma importância relativa de 8.5%. Esses resultados são condizentes com aqueles encontrados em pesquisas anteriores, por exemplo, Medina-Salgado et al. (2022) que demonstram a eficácia dos modelos ML que incorporam variáveis espaciais e temporais nas estimativas de tráfego de veículos.

Figura 4 - Contribuição relativa acumulada (%) das variáveis utilizadas pelo RF para estimar fluxos de veículos e velocidade média ao nível da via na cidade do Rio de Janeiro no período entre 7 a 31 de janeiro de 2021.



Elaborado pelos autores, 2024.

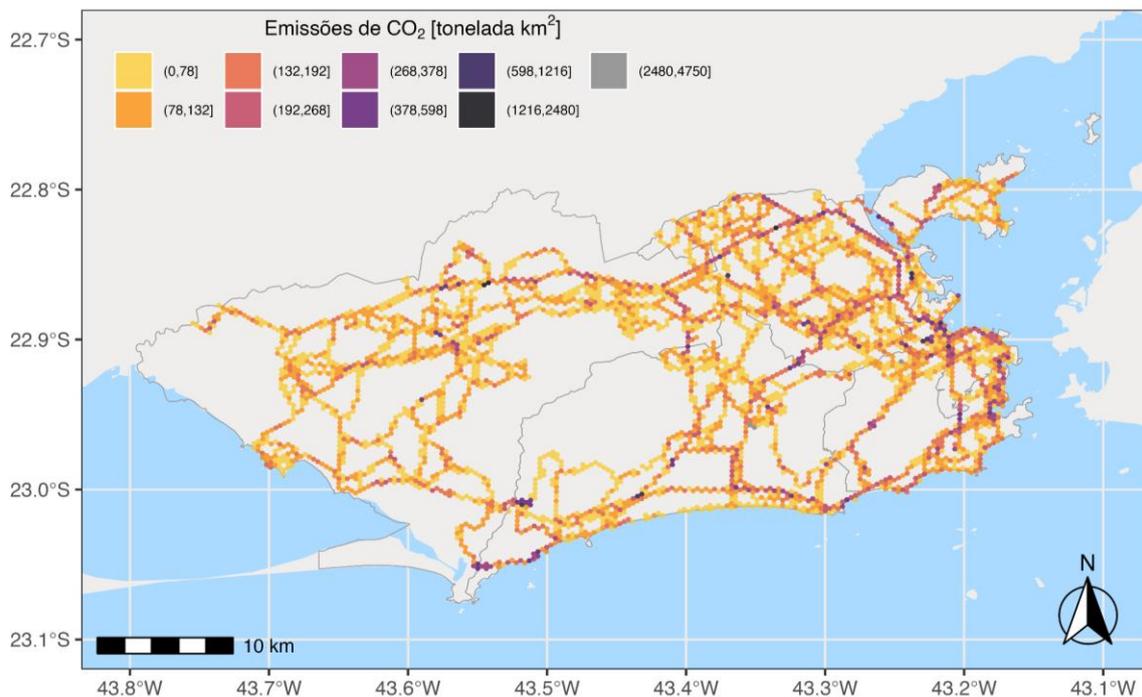
Distribuição espaço-temporal das emissões de CO₂

O modelo ML foi empregado para estimar as emissões veiculares de CO₂ considerando a soma das emissões de todos os tipos de veículos agregadas às malhas digitais do IPEA durante o período de 7 a 31 de

janeiro de 2021 (Figura 5). No mapa observam-se emissões elevadas nas principais vias expressas da cidade, com o máximo de 4.750 tCO₂ km⁻² na Avenida Brasil. Essas vias são caracterizadas principalmente por possuírem mais pistas de rolamento, o que resulta em um maior número de veículos, fluxo intenso, alta velocidade e longa extensão, contribuindo para emissões mais elevadas de CO₂.

Além disso, essas vias expressas desempenham um papel crucial como grandes corredores de transporte rodoviário, conectando a cidade a outras regiões, facilitando o deslocamento dos moradores da periferia para o Rio de Janeiro. São vias expressas importantes, como a Linha Vermelha, Linha Amarela, Transolímpica, Transoeste, TransCarioca e Aterro do Flamengo. Essas vias direcionam o tráfego, principalmente, para o Centro, Zona Sul e, mais recentemente, para a Barra da Tijuca, que são os principais polos empregatícios da cidade.

Figura 5 – Emissões de CO₂ originárias do tráfego de veículos (tCO₂ km⁻²) na cidade do Rio de Janeiro. As emissões correspondem à soma dos valores por via agregadas ao grid de 100 x 100 metros no período entre 7 a 31 de janeiro de 2021.



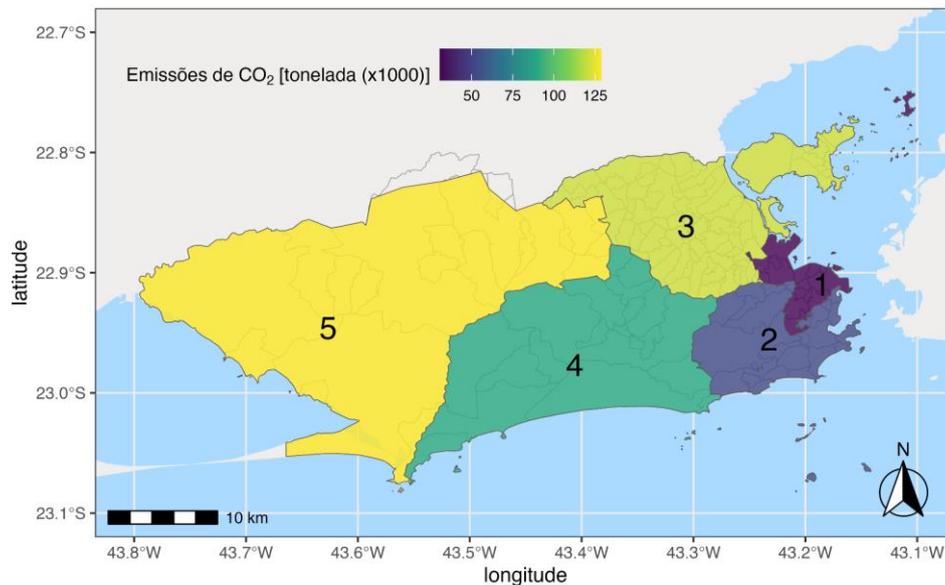
Fonte: Base cartográfica- OpenStreetMap, 2017; dados de tráfego CET-Rio, 2021.
Elaborado pelos autores, 2024.

Emissões de CO₂ e Áreas de Planejamento

Para analisar as características socioespaciais das emissões de CO₂, os valores estimados pelo modelo ML foram agregados à malha do IPEA, às APs e RPs. A Figura 6 mostra a distribuição espacial dos acumulados de emissões de CO₂ por AP durante o período analisado. A AP 5 se destacou com a maior parcela

de emissões, totalizando aproximadamente 128 mil tCO₂, seguida pela AP 3 com 120 mil tCO₂, a AP 4 com 90 mil tCO₂, a AP 2 com 52 mil tCO₂, e, a AP 1 com 30 mil tCO₂. A AP5 tem maior extensão, cobre quase a metade da área da cidade, um maior número de vias, o que provavelmente contribuiu para a maior emissão total.

Figura 6 – Emissões de tráfego de veículos em toneladas de CO₂ (x1000) por AP no Rio de Janeiro, no período entre 7 a 31 de janeiro de 2021.



Elaborado pelos autores, 2024.

Para comparar as emissões das APs, independentemente de sua extensão, foram calculadas as emissões *per capita*, e o resultado foi bem diferente. As APs com maior emissão *per capita* foram aquelas que têm menor população AP 1 (100 Kg CO₂ per capita) e AP 4 (96 Kg CO₂ per capita), respectivamente a antiga e a nova centralidade da cidade do Rio de Janeiro (COSENTINO, 2016). Áreas que concentram atividades e têm maior acessibilidade, e, por consequência, convergem os fluxos que sustentam as relações no território da cidade do Rio de Janeiro (PEREIRA, 2022b). Foram seguidas pela AP 5 (79 Kg CO₂ per capita), AP 2 (50 Kg CO₂ per capita) e AP 3 (49 Kg CO₂ per capita), as duas últimas são as áreas de maior densidade demográfica na cidade.

Emissões de CO₂ e variáveis socioeconômicas

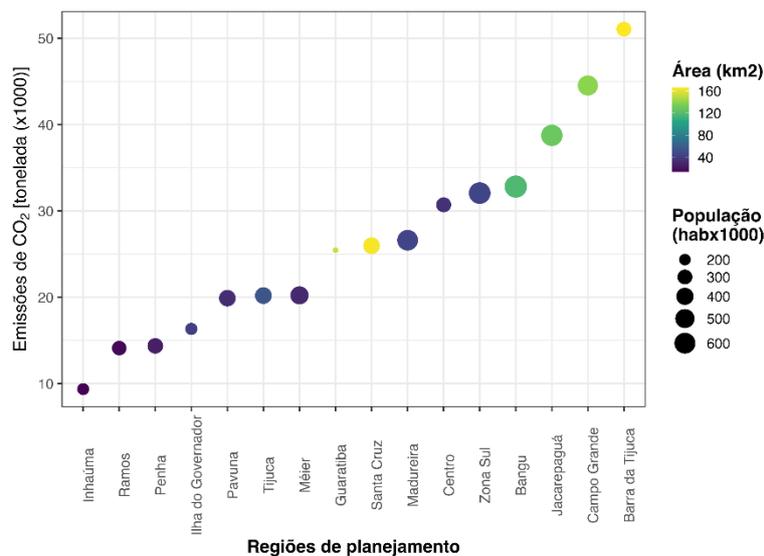
Na figura 7, uma análise mais detalhada das APs revelou que as emissões de CO₂ variaram consideravelmente, indo do menor total de 9.367 t em Inhaúma (RP 3.4) para o máximo de 51.066 t na Barra



da Tijuca (RP 4.2). Em Inhaúma, apesar de uma densidade demográfica bem mais alta, população de 209 mil habitantes em menos de 14 km² de área, as emissões de CO₂ são relativamente baixas. Por outro lado, na Barra da Tijuca, com menor densidade demográfica, população de aproximadamente 300 mil habitantes em uma área de 166 km², as emissões são mais elevadas.

Outro destaque é o caso de Guaratiba (RP 5.4) que tem a menor população entre todas as RPs (126 mil habitantes), mas ainda assim apresenta totais de emissões de CO₂ (25.464 ton) semelhantes a Santa Cruz (RP 5.3) (25.986 ton), RP vizinha com área similar (164 km²), mas população bem superior (377 mil habitantes). Isso sugere que as emissões veiculares de CO₂ não seguem uma relação linear com o número de habitantes, com a extensão da área ocupada nem mesmo com a densidade demográfica.

Figura 7 - Emissões de tráfego de veículos em toneladas de CO₂ por área ocupada e densidade populacional em cada RP no Rio de Janeiro.



Elaborado pelos autores, 2024.

Esses resultados indicam que os fluxos no espaço da cidade, influenciados por fatores como o tipo de atividades socioeconômicas, a infraestrutura viária, o transporte público e o uso do solo, desempenham um papel importante na determinação das maiores emissões de CO₂ em áreas centrais no Rio de Janeiro.

Na tabela 1, com as RPs dispostas segundo os totais de emissão de CO₂, é possível observar que as seis RPs com maior emissão possuem algumas características comuns. Por exemplo, Barra da Tijuca, Campo Grande, Jacarepaguá e Bangu possuem dimensões territoriais semelhantes (aproximadamente 120 km²), o que pode justificar as elevadas emissões devido à concentração de vias expressas com um intenso fluxo de



veículos. Por outro lado, Centro, Zona Sul e Barra da Tijuca apresentam as maiores ofertas de postos de trabalho, tanto em termos de quantidade total (variando entre 74.600 e 336.911) quanto com base no nível de escolaridade (8 - 23%). Isto reflete a centralidade destas áreas, para onde convergem os fluxos de veículos, o que também pode explicar as elevadas emissões de CO₂. No entanto, em termos de renda per capita, a RP Centro diverge da Zona Sul e Barra da Tijuca, pois estas últimas apresentam os maiores valores. Assim, a Barra da Tijuca destaca-se com a maior emissão por apresentar as características mencionadas nos diferentes grupos (dimensão, oferta de emprego e renda).

Tabela 1– Emissões de tráfego de veículos em tCO₂, renda domiciliar per capita média e totais de empregos por RP no Rio de Janeiro.

Região de Planejamento	Emissões CO ₂ (T)	Renda per capita média (R\$)	Empregos				
			Total	Total (%)	Baixa escolaridade (% do total)	Média escolaridade (% do total)	Alta escolaridade (% do total)
Barra da Tijuca	51.066	2.323	150.513	9,4	8,78	9,61	9,54
Campo Grande	44.540	635	74.600	4,7	4,06	5,62	2,89
Jacarepaguá	38.761	1.069	122.596	7,7	7,96	8,1	6,18
Bangu	32.830	656	59.789	3,7	3,93	4,17	2,41
Zona Sul	32.079	3.044	293.263	18,3	20,14	15,55	23,16
Centro	30.718	845	336.911	21,0	15,4	19,41	31,49
Madureira	26.616	803	94.988	5,9	6,89	6,49	3,41
Santa Cruz	25.981	421	37.418	2,3	1,99	2,69	1,84
Guaratiba	25.464	518	10.901	0,7	0,75	0,77	0,38
Méier	20.235	953	83.085	5,2	5,71	5,48	3,84
Tijuca	20.205	1.739	110.521	6,9	7,56	6,78	6,43
Pavuna	19.906	528	40.875	2,6	3,3	2,7	1,33
I. Governador	16.341	1.277	25.103	1,6	1,78	1,61	1,21
Penha	14.376	666	60.951	3,8	4,52	4,23	1,92
Ramos	14.118	595	60.918	3,8	4,46	4,12	2,26
Inhaúma	9.367	649	39.762	2,5	2,77	2,66	1,71

Elaborado pelos autores, 2024.



CONSIDERAÇÕES FINAIS

Este estudo demonstrou que as características socioeconômicas são importantes vetores para explicar as variações espaço-temporais das emissões de CO₂ originárias do tráfego de veículos nas cidades. Usando algoritmos de inteligência artificial, a modelagem em alta definição apresentou um quadro geral das emissões de CO₂ em toda área da cidade e ajudou a identificar *hotspot* nas vias expressas, principalmente nas horas de pico.

As vias expressas, utilizadas como modelo de transporte para deslocamento rápido pela cidade, concentram um número maior de veículos que conseguem desenvolver maior velocidade por um percurso mais longo, emitindo mais CO₂. No entanto, como a taxa de motorização dos veículos particulares quase triplicou nas últimas décadas - passando de 16,9 em 1994, para 45,8 em 2021 (PCRJ, 2022) - mesmo as vias expressas apresentam congestionamento cotidianamente, o que também contribui com mais emissão de CO₂. Esse é o resultado de um modelo que privilegia o transporte individual em detrimento do uso de transporte coletivo que, opostamente, vem apresentando redução da taxa de motorização para veículos coletivos nos últimos anos visto que também apresentou redução significativa no número de passageiros transportados.

Os resultados alcançados com os indicadores sociais reforçam conclusões verificadas nos referenciais teóricos. Na cidade do Rio de Janeiro, a oferta de trabalho tem concentração espacial em áreas onde há menos população residindo, como é o caso da AP1, AP2 e mais recentemente a AP4, o que exige a necessidade da mobilidade e conseqüentemente, impactam nas emissões. Além disso, nessas áreas de menor população a renda é maior (AP2 e AP4), o que influenciou na variação das emissões de CO₂.

A Zona Sul, área mais nobre da cidade, está próxima da área central, e juntas concentram a maioria dos postos de trabalho, para onde destinam-se os fluxos de veículos. Historicamente, a Barra da Tijuca surge como extensão da Zona Sul, e na última década recebeu investimentos em mobilidade urbana por conta dos Jogos Olímpicos. Esses investimentos incluíram a criação de novos modais (Linha 4 do metrô e BRTs), uma via expressa (Transolímpica) e corredores viários para os BRTs (Transoeste e Transcarioca) melhorando a conexão desta área economicamente emergente com as demais APs. Como resultado, a Barra da Tijuca se tornou uma nova centralidade de fluxos, concentrando as emissões de CO₂.



AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001" e a Fundação Alexander von Humboldt, Alemanha. Apoio da Faperj - Fundação Carlos Chagas Filho de Amparo à Pesquisa do Estado do Rio de Janeiro pelo financiamento da pesquisa através do Edital para Grupos Emergentes. Os autores agradecem a CET-Rio pelo fornecimento dos dados de tráfego.

REFERÊNCIAS

- ABREU, M. A. Evolução urbana no Rio de Janeiro. 1987.
- BREIMAN, L. Random Forests. **Mach Learn.** vol. 45, p.5–32, 2001.
- CARVALHO, C. H. R. Emissões relativas de poluentes do transporte motorizado de passageiros nos grandes centros urbanos brasileiros. Texto para Discussão, No. 1606, **Instituto de Pesquisa Econômica Aplicada (IPEA)**, Brasília, 2011.
- CHIQUETTO, J. B. et al. Socioeconomic conditions and fossil fuel CO₂ in the Metropolitan Area of Rio de Janeiro. **Urban Climate** 43 (2022) 101176. Disponível em: <https://doi.org/10.1016/j.uclim.2022.101176>. Acesso em: 16 out 2022.
- CHURKINA, G. The Role of Urbanization in the Global Carbon Cycle. **Front. Ecol. Evol.** v.144, n.3, 2016.
- COSENTINO, R. Olimpíadas da Barra da Tijuca 2016: A construção de uma nova centralidade no Rio de Janeiro. In: VAINER, Carlos; BROUDEHOUX, A.; SÁNCHEZ, F.; OLIVEIRA, F. L. (orgs.). **Os megaeventos e a cidade: perspectivas críticas**. Rio de Janeiro: Letra Capital, 2016.
- FENG S, et al. LA megacity: A high-resolution land-atmosphere modelling system for urban CO₂ emissions. **Atmos Chem Phys.** 16:9019–9045, 2016.
- GATELY, C.K. et al. Cities, traffic, and CO₂: A multidecadal assessment of trends, drivers, and scaling relationships. **Proceedings of the National Academy of Sciences**, v. 112, n. 16, p. 4999-5004, 2015.
- GELADI, P., KOWALSKI B. R. Partial least-squares regression: a tutorial. **Analytica chimica acta**, 185, 1-17, 1986.
- GUIMARÃES, R. C. V. Barra da Tijuca e o Projeto Olímpico: a cidade da capital. Rio de Janeiro. Dissertação de Mestrado. IPPUR. UFRJ. 153 p, 2015.
- GURNEY, K. R. et al. Quantification of fossil fuel CO₂ emissions on the building/street scale for a large US city. **Environmental science & technology**, v. 46, n. 21, p. 12194-12202, 2012.
- QGIS.org. QGIS Geographic Information System. QGIS Association. <http://www.qgis.org>. 2023.



- HARDIMAN, B. S. et al. Accounting for urban biogenic fluxes in regional carbon budgets. **Science of the Total Environment**, v. 592, p. 366-372, 2017.
- HUNDERTMARK, W.J. et al. Influence of landscape management practices on urban greenhouse gas budgets. **Carbon Balance Manage**, 16:1, 2021. Disponível em: <https://doi.org/10.1186/s13021-020-00160-5>. Acesso em: 17 dez 2022.
- HUO D, HUANG X, DOU X, CIAIS P, LI Y, DENG Z, ET AL. Carbon Monitor Cities near-real-time daily estimates of CO₂ emissions from 1500 cities worldwide. **Sci Data**. v.533, n.9, 2022.
- KUHN, M., JOHNSON, K. Applied predictive modeling. New York: **Springer**; 2013.
- KUHN M, WICKHAM H, HVITFELDT E. recipes: Preprocessing and Feature Engineering Steps for Modeling. <https://github.com/tidymodels/recipes>, <https://recipes.tidymodels.org/>. 2023.
- LAUVAUX, T. et al. High-resolution atmospheric inversion of urban CO₂ emissions during the dormant season of the Indianapolis Flux Experiment (INFLUX). **Journal of Geophysical Research: Atmospheres**, v. 121, n. 10, p. 5213-5236, 2016.
- LU, H. et al. Spatial Pattern of Residential Carbon Dioxide Emissions in a Rapidly Urbanizing Chinese City and Its Mismatch Effect. **Sustainability** 10, no. 3: 827, 2018.
- MASCARENHAS, G. Rio de Janeiro 2016: a cidade em movimento. **Revista USP**, n. 108, p. 49-56, 2016.
- MENZER, O. et al. Annual sums of carbon dioxide exchange over a heterogeneous urban landscape through machine learning based gap-filling. **Atmospheric Environment**, v. 101, p. 312-327, 2015.
- MITCHELL, L.E. et al. Long-term urban carbon dioxide observations reveal spatial and temporal dynamics related to urban characteristics and growth. **Proc. Natl. Acad. Sci. U. S. A.** 115 (12), 2912–2917, 2018. Disponível em: <https://doi.org/10.1073/pnas.1702393115>. Acesso em: 03 dez 2022.
- NOTTER, B., et al. "HBEFA 4.1." INFRAS, 2019.
- NOVAIS, P. Urbanismo na cidade desigual: o Rio de Janeiro e os megaeventos. **Revista Brasileira de Estudos Urbanos e Regionais** – v.16, n.1, pp. 11-34, 2014.
- OLIVEIRA, F.G. e OLIVEIRA, L.D. Espaço metropolitano, regionalização da economia e reestruturação produtiva no estado do Rio de Janeiro, Brasil. Cuyonomics. **Investigaciones en Economía Regional**. Año 3, número 5, pp. 39-65, 2020.
- OPENSTREETMAP.http://wiki.openstreetmap.org/wiki/About_OpenStreetMap. 2022, Acessado 13 de maio de 2024.
- PARK, C. et al. Spatiotemporal variations in urban CO₂ flux with land-use types in Seoul. **Carbon Balance and Management**. 17:3, 2022. Disponível em: <https://doi.org/10.1186/s13021-022-00206-w>. Acesso em: 16 dez 2022.
- PATAKI, D.E. et al. Coupling biogeochemical cycles in urban environments: ecosystem services, green solutions, and misconceptions. **Front. Ecol. Environ.** 9, 27e36, 2011. Disponível em: <http://dx.doi.org/10.1890/090220>. Acesso em: 03 dez 2022.



PCRJ. Instituto Pereira Passos. **População e taxa de motorização por tipo de veículo no Município do Rio de Janeiro entre 1994-2021**. Prefeitura da Cidade do Rio de Janeiro, 2022. Disponível em: <https://www.data.rio/documents/PCRJ::população-e-taxa-de-motorização-por-tipo-de-veículo-no-município-do-rio-de-janeiro-entre-1994-2021/about>. Acesso em: 11 dez 2022.

PEREIRA, R.H. et al. Distributional effects of transport policies on inequalities in access to opportunities in Rio de Janeiro. **J. Transp. Land Use** 12 (1), 741–764, 2019a. Disponível em: <https://doi.org/10.5198/jtlu.2019.1523>. Acesso em: 01 dez 2022.

PEREIRA, D.M. **O eixo Centro Metropolitano: o novo espaço de expansão da centralidade da Barra da Tijuca**. 96 f. Dissertação (Programa de Pós-Graduação em Geografia) - Universidade do Estado do Rio de Janeiro, Rio de Janeiro 2022b.

R CORE TEAM. A Language and Environment for Statistical Computing [Internet]. Vienna: **R Foundation for Statistical Computing**. Disponível em: <https://www.R-project.org/>, 2023. Acesso em: 21 fev. 2023.

RIO DE JANEIRO (Município). Lei Complementar nº111. 2011. Plano Diretor de Desenvolvimento Urbano Sustentável do Município do Rio de Janeiro. 2024. 379 p.

RIO DE JANEIRO (Município). Lei Complementar nº270. 2024. Plano Diretor de Desenvolvimento Urbano Sustentável do Município do Rio de Janeiro. 2011. 188 p.

RODRIGUES, J. M. Condições de mobilidade urbana e organização social do território. Em: Ribeiro, L.C.Q. Rio de Janeiro: transformações na ordem urbana. Letra Capital/Observatório das Metrôpoles: Rio de Janeiro, 2015.

SARGENT, M. et al. Anthropogenic and biogenic CO₂ fluxes in the Boston urban region. **Proceedings of the National Academy of Sciences**, v. 115, n. 29, p. 7491-7496, 2018.

SOUZA M. L. ABC do Desenvolvimento Urbano. Rio de Janeiro: Bertrand Brasil, 222 p., 2003.

TURNBULL, J. IG3IS Urban Greenhouse Gas Emission Observation and Monitoring Best Research Practices. World Meteorological Organization Integrated Greenhouse Gas Information System, [online]. Disponível em: <https://ig3is.wmo.int/> Acesso em: 05 dez 2022.

VELASCO, E., ROTH, M. Cities as net sources of CO₂: review of atmospheric CO₂ exchange in urban environments measured by eddy covariance technique. **Geogr. Compass** 4, 1238e1259. 2010. Disponível em: <http://dx.doi.org/10.1111/j.1749-%208198.2010.00384.x>. Acesso em: 01 dez 2022.

WANG, S. et al. Examining the impacts of socioeconomic factors, urban form, and transportation networks on CO₂ emissions in China's megacities. **Applied energy**, 185, 189-200, 2017.

WARD, H.C. et al. Effects of urban density on carbon dioxide exchanges: Observations of dense urban, suburban and woodland areas of southern England. **Environmental Pollution**. Volume 198, pp 186-200, March 2015. Disponível em: <http://dx.doi.org/10.1016/j.envpol.2014.12.031>. Acesso em: 02 dez 2022.

WRIGHT MN, ZIEGLER A. "ranger: A Fast Implementation of Random Forests for High Dimensional Data in C++ and R." *Journal of Statistical Software*, 77(1), 1–17. 2017. doi:10.18637/jss.v077.i01.



WU, D. et al. A model for urban biogenic CO₂ fluxes: Solar-Induced Fluorescence for Modeling Urban biogenic Fluxes (SMUrF v1), **Geosci. Model Dev.**, 14, 3633–3661, 2021. Disponível em: <https://doi.org/10.5194/gmd-14-3633-2021,%202021>. Acesso em: 01 dez 2022.